

18.4 Das Newton-Verfahren

Ziel: Wir suchen die Nullstellen einer Funktion $\mathbf{f} : D \rightarrow \mathbb{R}^n$, $D \subset \mathbb{R}^n$:

$$\mathbf{f}(\mathbf{x}) = \mathbf{0}$$

- Wir kennen bereits die **Fixpunktiteration**

$$\mathbf{x}^{k+1} := \Phi(\mathbf{x}^k)$$

mit Startwert \mathbf{x}^0 und Iterationsvorschrift $\Phi : \mathbb{R}^n \rightarrow \mathbb{R}^n$.

- Konvergenzaussagen liefert der **Banachsche Fixpunktsatz**.

Vorteil: Dieses Verfahren ist **ableitungsfrei**

Nachteile:

- numerisches Verfahren konvergiert zu langsam (nur linear),
- es gibt keine eindeutige Iterationsvorschrift.

Zur Konstruktion des Newton-Verfahrens.

Ausgangspunkt: Gegeben sei eine C^1 -Funktion $\mathbf{f} : D \rightarrow \mathbb{R}^n$, $D \subset \mathbb{R}^n$ offen.

Wir suchen *eine* Nullstelle von \mathbf{f} , d.h. ein $\mathbf{x}^* \in D$ mit

$$\mathbf{f}(\mathbf{x}^*) = \mathbf{0}$$

Konstruktion des Newton-Verfahrens: Die Taylor-Entwicklung von $\mathbf{f}(\mathbf{x})$ um einen Startwert \mathbf{x}^0 lautet

$$\mathbf{f}(\mathbf{x}) = \mathbf{f}(\mathbf{x}^0) + \mathbf{Jf}(\mathbf{x}^0)(\mathbf{x} - \mathbf{x}^0) + \mathbf{o}(\|\mathbf{x} - \mathbf{x}^0\|)$$

Setzen wir $\mathbf{x} = \mathbf{x}^*$, so folgt

$$\mathbf{Jf}(\mathbf{x}^0)(\mathbf{x}^* - \mathbf{x}^0) \approx -\mathbf{f}(\mathbf{x}^0)$$

Eine Näherungslösung für \mathbf{x}^* ist dann \mathbf{x}^1 , $\mathbf{x}^1 \approx \mathbf{x}^*$, die Lösung des linearen Gleichungssystems

$$\mathbf{Jf}(\mathbf{x}^0)(\mathbf{x}^1 - \mathbf{x}^0) = -\mathbf{f}(\mathbf{x}^0)$$

Das Newton-Verfahren als Algorithmus.

Das **Newton-Verfahren** kann man somit wie folgt als Algorithmus formulieren.

Algorithmus (Newton-Verfahren):

(1) FOR $k = 0, 1, 2, \dots$

(2a) Löse $\mathbf{Jf}(\mathbf{x}^k) \cdot \Delta \mathbf{x}^k = -\mathbf{f}(\mathbf{x}^k)$;

(2b) Setze $\mathbf{x}^{k+1} := \mathbf{x}^k + \Delta \mathbf{x}^k$;

- Man löst im *jedem* Newton-Schritt ein lineares Gleichungssystem.
- Dessen Lösung $\Delta \mathbf{x}^k$ heißt **Newton-Korrektur**.
- Das Newton-Verfahren ist **skalierungsinvariant**. □

Invarianzen des Newton-Verfahrens.

Satz: *Das Newton-Verfahren ist invariant unter linearen Transformationen der Form*

$$\mathbf{f}(\mathbf{x}) \rightarrow \mathbf{g}(\mathbf{x}) = \mathbf{A}\mathbf{f}(\mathbf{x}) \quad \text{für } \mathbf{A} \in \mathbb{R}^{n \times n} \text{ regulär,}$$

d.h. die Iterierten für \mathbf{f} und \mathbf{g} sind in diesem Fall identisch.

Beweis: Bildet man das Newton-Verfahren für $\mathbf{g}(\mathbf{x})$, so lautet die Newton-Korrektur

$$\begin{aligned} \Delta \mathbf{x}^k &= -(\mathbf{J}\mathbf{g}(\mathbf{x}^k))^{-1} \cdot \mathbf{g}(\mathbf{x}^k) \\ &= -(\mathbf{A}\mathbf{J}\mathbf{f}(\mathbf{x}^k))^{-1} \cdot \mathbf{A}\mathbf{f}(\mathbf{x}^k) \\ &= -(\mathbf{J}\mathbf{f}(\mathbf{x}^k))^{-1} \cdot \mathbf{f}(\mathbf{x}^k) \end{aligned}$$

womit die Newton-Korrekturen von \mathbf{f} und \mathbf{g} übereinstimmen.

Bei gleichem Startwert \mathbf{x}^0 stimmen somit auch alle Iterierten \mathbf{x}^k überein. ■

Zur lokalen Konvergenz des Newton-Verfahrens.

Satz: Sei $f : D \rightarrow \mathbb{R}^n$ eine C^1 -Funktion, $D \subset \mathbb{R}^n$ offen und konvex. Sei $\mathbf{x}^* \in D$ Nullstelle von \mathbf{f} , d.h. $\mathbf{f}(\mathbf{x}^*) = 0$. Weiterhin sei die Jacobi-Matrix $\mathbf{Jf}(\mathbf{x})$ regulär für $\mathbf{x} \in D$, und es gelte eine **Lipschitz-Bedingung**

$$\|(\mathbf{Jf}(\mathbf{x}))^{-1}(\mathbf{Jf}(\mathbf{y}) - \mathbf{Jf}(\mathbf{x}))\| \leq L\|\mathbf{y} - \mathbf{x}\| \quad \text{für alle } \mathbf{x}, \mathbf{y} \in D,$$

mit einem $L > 0$. Dann ist das Newton-Verfahren für alle Startwerte $\mathbf{x}^0 \in D$ mit

$$\|\mathbf{x}^0 - \mathbf{x}^*\| < \frac{2}{L} =: r \quad \text{und} \quad K_r(\mathbf{x}^*) \subset D$$

wohldefiniert mit $\mathbf{x}^k \in K_r(\mathbf{x}^*)$, $k = 0, 1, 2, \dots$, und die Newton-Iterierten \mathbf{x}^k konvergieren **quadratisch** gegen \mathbf{x}^* , d.h.

$$\|\mathbf{x}^{k+1} - \mathbf{x}^*\| \leq \frac{L}{2} \|\mathbf{x}^k - \mathbf{x}^*\|^2.$$

Weiterhin ist \mathbf{x}^* die eindeutige Nullstelle von $\mathbf{f}(\mathbf{x})$ innerhalb der Kugel $K_r(\mathbf{x}^*)$.

Beweis: Betrachte für $\mathbf{x}, \mathbf{y} \in D$ die Funktion

$$\varphi(t) = (\mathbf{Jf}(\mathbf{x}))^{-1} \cdot \mathbf{f}(\mathbf{x} + t(\mathbf{y} - \mathbf{x})) \quad \text{für } t \in [0, 1].$$

Dann ist $\varphi(t)$ stetig differenzierbar mit

$$\varphi'(t) = (\mathbf{Jf}(\mathbf{x}))^{-1} \cdot \mathbf{Jf}(\mathbf{x} + t(\mathbf{y} - \mathbf{x})) \cdot (\mathbf{y} - \mathbf{x})$$

und daraus folgt

$$\begin{aligned} \|\varphi'(t) - \varphi'(0)\| &= \|(\mathbf{Jf}(\mathbf{x}))^{-1} (\mathbf{Jf}(\mathbf{x} + t(\mathbf{y} - \mathbf{x})) - \mathbf{Jf}(\mathbf{x})) (\mathbf{y} - \mathbf{x})\| \\ &\leq \|(\mathbf{Jf}(\mathbf{x}))^{-1} (\mathbf{Jf}(\mathbf{x} + t(\mathbf{y} - \mathbf{x})) - \mathbf{Jf}(\mathbf{x}))\| \|\mathbf{y} - \mathbf{x}\| \\ &\leq L \cdot t \cdot \|\mathbf{y} - \mathbf{x}\|^2. \end{aligned}$$

Hieraus erhält man weiterhin die folgende Abschätzung.

$$\begin{aligned}\|(\mathbf{Jf}(\mathbf{x}))^{-1}(\mathbf{f}(\mathbf{y}) - \mathbf{f}(\mathbf{x}) - \mathbf{Jf}(\mathbf{x})(\mathbf{y} - \mathbf{x}))\| &= \|\varphi(1) - \varphi(0) - \varphi'(0)\| \\ &\leq \left\| \int_0^1 (\varphi'(t) - \varphi'(0)) dt \right\| \\ &\leq \int_0^1 \|\varphi'(t) - \varphi'(0)\| dt \\ &\leq \int_0^1 L \cdot t \cdot \|\mathbf{y} - \mathbf{x}\|^2 dt = \frac{L}{2} \|\mathbf{y} - \mathbf{x}\|^2\end{aligned}$$

Den Fehler der Newton-Iteration stellen wir folgendermaßen dar.

$$\begin{aligned}\mathbf{x}^{k+1} - \mathbf{x}^* &= \mathbf{x}^k - (\mathbf{Jf}(\mathbf{x}^k))^{-1} \mathbf{f}(\mathbf{x}^k) - \mathbf{x}^* \\ &= -(\mathbf{Jf}(\mathbf{x}^k))^{-1} (\mathbf{f}(\mathbf{x}^k) - \mathbf{f}(\mathbf{x}^*)) + (\mathbf{x}^k - \mathbf{x}^*) \\ &= (\mathbf{Jf}(\mathbf{x}^k))^{-1} (\mathbf{f}(\mathbf{x}^*) - \mathbf{f}(\mathbf{x}^k) - \mathbf{Jf}(\mathbf{x}^k)(\mathbf{x}^* - \mathbf{x}^k)).\end{aligned}$$

Daraus bekommen wir für $0 < \|\mathbf{x}^k - \mathbf{x}^*\| < r = \frac{2}{L}$ die Abschätzung

$$\|\mathbf{x}^{k+1} - \mathbf{x}^*\| \leq \frac{L}{2} \|\mathbf{x}^k - \mathbf{x}^*\|^2 < \frac{L}{2} \cdot r \|\mathbf{x}^k - \mathbf{x}^*\| = \|\mathbf{x}^k - \mathbf{x}^*\|.$$

Die nichtnegative Folge $\|\mathbf{x}^k - \mathbf{x}^*\|$ ist somit streng monoton fallend und daher konvergent, gegen eine reelle Zahl d mit $0 \leq d < r = 2/L$ und $d \leq L/2 \cdot d^2$, woraus $d = 0$ folgt. Somit konvergiert die Folge $\{\mathbf{x}^k\}$.

Die Nullstelle \mathbf{x}^* ist eindeutig. Denn gäbe es eine weitere Nullstelle $\mathbf{x}^{**} \in K_r(\mathbf{x}^*)$ von \mathbf{f} , so folgt ein Widerspruch mit

$$\begin{aligned} \|\mathbf{x}^{**} - \mathbf{x}^*\| &= \|(\mathbf{Jf}(\mathbf{x}^*))^{-1} (\mathbf{f}(\mathbf{x}^{**}) - \mathbf{f}(\mathbf{x}^*) - \mathbf{Jf}(\mathbf{x}^*)(\mathbf{x}^* - \mathbf{x}^{**}))\| \\ &\leq \frac{L}{2} \|\mathbf{x}^{**} - \mathbf{x}^*\|^2 < \|\mathbf{x}^{**} - \mathbf{x}^*\|. \end{aligned}$$

Somit ist \mathbf{x}^* einzige Nullstelle von \mathbf{f} in $K_r(\mathbf{x}^*)$. ■

Das gedämpfte Newton-Verfahren.

- Das Newton-Verfahren konvergiert zwar quadratisch, aber nur **lokal**.
- **Globale** Konvergenz kann ggf. durch einen Dämpfungsterm erreicht werden:

Algorithmus (Gedämpftes Newton-Verfahren):

(1) **FOR** $k = 0, 1, 2, \dots$

(2a) **Löse** $\mathbf{J}f(\mathbf{x}^k) \cdot \Delta\mathbf{x}^k = -f(\mathbf{x}^k)$;

(2b) **Setze** $\mathbf{x}^{k+1} := \mathbf{x}^k + \lambda_k \Delta\mathbf{x}^k$;

Frage: Wie wählt man die **Dämpfungsfaktoren** λ_k ?

Strategie: Verwende eine **Testfunktion** $T(\mathbf{x}) = \|\mathbf{f}(\mathbf{x})\|$, womit gilt

$$T(\mathbf{x}) \geq 0, \quad \forall \mathbf{x} \in D$$

$$T(\mathbf{x}) = 0 \quad \iff \quad \mathbf{f}(\mathbf{x}) = \mathbf{0}.$$

Wahl des Dämpfungsparameters.

Wähle nun $\lambda_k \in (0, 1]$, so dass die Folge $T(\mathbf{x}^k)$ streng monoton fällt, d.h.

$$\|\mathbf{f}(\mathbf{x}^{k+1})\| < \|\mathbf{f}(\mathbf{x}^k)\| \quad \text{für } k \geq 0.$$

- *In der Nähe* der gesuchten Lösung \mathbf{x}^* sollte $\lambda_k = 1$ gewählt werden, um (lokale) quadratische Konvergenz zu sichern.

Der folgende Satz garantiert die Existenz eines Dämpfungsparameters.

Satz: Sei \mathbf{f} eine C^1 -Funktion auf der offenen und konvexen Menge $D \subset \mathbb{R}^n$. Für $\mathbf{x}^k \in D$ mit $\mathbf{f}(\mathbf{x}^k) \neq \mathbf{0}$ gibt es dann ein $\mu_k > 0$, so dass

$$\|\mathbf{f}(\mathbf{x}^k + \lambda \Delta \mathbf{x}^k)\|_2^2 < \|\mathbf{f}(\mathbf{x}^k)\|_2^2 \quad \text{für alle } \lambda \in (0, \mu_k).$$

Beweis: Betrachte die C^1 -Funktion

$$\varphi(\lambda) = \|\mathbf{f}(\mathbf{x}^k + \lambda\Delta\mathbf{x}^k)\|_2^2$$

für $\lambda \in (-\epsilon, \epsilon)$, mit $\epsilon > 0$.

Dann gilt

$$\varphi(0) = \|\mathbf{f}(\mathbf{x}^k)\|_2^2 > 0$$

sowie

$$\varphi'(0) = 2(\mathbf{f}(\mathbf{x}^k))^T \mathbf{J}\mathbf{f}(\mathbf{x}^k)\Delta\mathbf{x}^k = -2(\mathbf{f}(\mathbf{x}^k))^T \mathbf{f}(\mathbf{x}^k) < 0.$$

Somit fällt die Funktion $\varphi(\lambda)$ *streng monoton* in einem (hinreichend kleinen) Intervall um Null, $(0, \mu)$, wo gilt

$$\varphi(0) = \|\mathbf{f}(\mathbf{x}^k)\|_2^2 > \|\mathbf{f}(\mathbf{x}^k + \lambda\Delta\mathbf{x}^k)\|_2^2 = \varphi(\lambda) \quad \text{für alle } \lambda \in (0, \mu).$$



Dämpfungsstrategie.

Für die Startiteration: $k = 0$.

Wähle

$$\lambda_0 \in \left\{ 1, \frac{1}{2}, \frac{1}{4}, \dots, \lambda_{\min} \right\}$$

möglichst groß, so dass gilt

$$\|\mathbf{f}(\mathbf{x}^k)\|_2 > \|\mathbf{f}(\mathbf{x}^k + \lambda_0 \Delta \mathbf{x}^k)\|_2$$

Dämpfungsstrategie.

Für nachfolgende Iterationen: $k > 0$.

- Setze $\lambda_k = \lambda_{k-1}$.

IF $\|\mathbf{f}(\mathbf{x}^k)\|_2 > \|\mathbf{f}(\mathbf{x}^k + \lambda_k \Delta \mathbf{x}^k)\|_2$ **THEN**

- $\mathbf{x}^{k+1} := \mathbf{x}^k + \lambda_k \Delta \mathbf{x}^k$
- $\lambda_k := 2\lambda_k$, falls $\lambda_k < 1$.

ELSE

- Bestimme $\mu = \max\{\lambda_k/2, \lambda_k/4, \dots, \lambda_{\min}\}$ mit

$$\|\mathbf{f}(\mathbf{x}^k)\|_2 > \|\mathbf{f}(\mathbf{x}^k + \lambda_k \Delta \mathbf{x}^k)\|_2$$

- $\lambda_k := \mu$

END

Nichtlineare Ausgleichsprobleme.

Aufgabenstellung: Minimiere Funktion

$$g(\mathbf{x}) = \|\mathbf{F}(\mathbf{x}) - \mathbf{y}\|_2^2 \quad \text{für } \mathbf{x} \in \mathbb{R}^n,$$

wobei $\mathbf{y} = (y_1, \dots, y_m)^T \in \mathbb{R}^m$ **Messdaten**, $m \gg n$, und

$$\mathbf{F}(\mathbf{x}) = \begin{bmatrix} f(t_1; x_1, \dots, x_n) \\ \vdots \\ f(t_m; x_1, \dots, x_n) \end{bmatrix}$$

Werte der **Ansatzfunktion**

$$y = f(t; x_1, \dots, x_n)$$

zu (verschiedenen) **Messzeiten** t_1, \dots, t_m und

$$\mathbf{x} = (x_1, \dots, x_n)^T \in \mathbb{R}^n$$

gesuchte **Parameter** der Ansatzfunktion.

Konstruktion des Gauß-Newton-Verfahrens.

Startpunkt: Sei $\mathbf{x}^0 \approx \mathbf{x}^*$ Näherung an Lösung \mathbf{x}^* des Minimierungsproblems.

Konstruktion: Dann gilt mit Taylor-Entwicklung um \mathbf{x}^0 in erster Näherung

$$\mathbf{g}(\mathbf{x}) \approx \|\mathbf{F}(\mathbf{x}^0) + \mathbf{JF}(\mathbf{x}^0)(\mathbf{x} - \mathbf{x}^0) - \mathbf{y}\|_2^2$$

Algorithmus (Gauß-Newton-Verfahren):

(1) FOR $k = 0, 1, 2, \dots$

(2a) Löse Minimierungsaufgabe

$$\|\mathbf{JF}(\mathbf{x}^k)\Delta\mathbf{x}^k - (\mathbf{y} - \mathbf{F}(\mathbf{x}^k))\|_2^2 \longrightarrow \min_{\Delta\mathbf{x}^k}$$

durch **lineare Ausgleichsrechnung**.

(2b) Setze $\mathbf{x}^{k+1} := \mathbf{x}^k + \Delta\mathbf{x}^k$;

Beispiel.

Betrachte Ansatzfunktion

$$y = f(t, \mathbf{x}) = x_1 + x_2 \cdot \exp(tx_3)$$

und Messdaten

t_i	-5	-3	-1	1	3	5
y_i	127	151	379	421	460	426

Für Startwert $x_1^0 = 300$, $x_2^0 = -1$, $x_3^0 = -0.3$
liefert Gauss-Newton nach 13 Iterationen

$$x_1^* = 523.306 \quad x_2^* = -156.948 \quad x_3^* = -0.199665$$

